

日 本 国 特 許 庁  
JAPAN PATENT OFFICE

別紙添付の書類に記載されている事項は下記の出願書類に記載されている事項と同一であることを証明する。

This is to certify that the annexed is a true copy of the following application as filed with this Office.

出 願 年 月 日      2 0 0 3 年   2 月 1 9 日  
Date of Application:

出 願 番 号      特 願 2 0 0 3 - 0 4 1 5 0 7  
Application Number:


[ST. 10/C] :      [ J P 2 0 0 3 - 0 4 . 1 5 0 7 ]

出      願      人      富 士 重 工 業 株 式 有 限 公 司  
Applicant(s):

2 0 0 3 年   9 月 1 6 日

特許庁長官  
Commissioner,  
Japan Patent Office

今 井 康 夫



【書類名】 特許願

【整理番号】 RT016418

【提出日】 平成15年 2月19日

【あて先】 特許庁長官 殿

【国際特許分類】 B62D 6/00

【発明者】

【住所又は居所】 東京都新宿区西新宿一丁目 7 番 2 号 富士重工業株式会  
社内

【氏名】 鳥居 毅

【発明者】

【住所又は居所】 東京都新宿区西新宿一丁目 7 番 2 号 富士重工業株式会  
社内

【氏名】 瀬田 至

【特許出願人】

【識別番号】 000005348

【氏名又は名称】 富士重工業株式会社

【代理人】

【識別番号】 100101982

【弁理士】

【氏名又は名称】 久米川 正光

【手数料の表示】

【予納台帳番号】 060635

【納付金額】 21,000円

【提出物件の目録】

【物件名】 明細書 1

【物件名】 図面 1

【物件名】 要約書 1

【包括委任状番号】 9813871

【プルーフの要否】 要

【書類名】 明細書

【発明の名称】 車両運動モデルの生成装置および車両運動モデルの生成方法

【特許請求の範囲】

【請求項 1】

車両の運動状態を表す車両運動モデルの生成装置において、  
複数のノードを接続することによりネットワークが形成され、一のノードからの出力が所定の結合重み係数に応じて他のノードへ入力されるとともに、少なくとも一つのノードからの出力が自己のノードまたは他のノードへフィードバックされるループを有する第 1 のリカレントニューラルネットワークと、

遺伝的アルゴリズムを用いた学習則に基づいて、前記第 1 のリカレントニューラルネットワークにおける前記結合重み係数の最適解を決定する最適化部とを有し、

前記第 1 のリカレントニューラルネットワークは、所定の入力情報に基づき、車両の運動状態を表す第 1 のパラメータを出力することで、車両運動モデルとして機能することを特徴とする車両運動モデルの生成装置。

【請求項 2】

前記第 1 のリカレントニューラルネットワークは、一つ以上のノードで構成される入力層と、一つ以上のノードで構成される出力層とを少なくとも含む階層型の構造を有し、

前記最適化部は、隣接する層間の各ノードの接続を処理対象として前記結合重み係数の最適解を決定することを特徴とする請求項 1 に記載された車両運動モデルの生成装置。

【請求項 3】

前記第 1 のリカレントニューラルネットワークは、一のノードの出力が自己のノードを含む前記複数のノードのすべてへ入力され、かつ、前記複数のノードのそれぞれの出力が前記一のノードへ入力されるように前記ノードのそれぞれが相互に接続されており、

前記最適化部は、前記ノードのそれぞれにおける相互の接続を処理対象として前記結合重み係数の最適解を決定することを特徴とする請求項 1 に記載された車

両運動モデルの生成装置。

**【請求項 4】**

前記ノードのそれぞれは、シグモイド関数、または、シグモイド関数以外の非シグモイド関数を伝達関数として用いることを特徴とする請求項 1 から 3 のいずれかに記載された車両運動モデルの生成装置。

**【請求項 5】**

前記第 1 のリカレントニューラルネットワークとは異なるネットワークを構成し、前記第 1 のパラメータとは異なる車両の運動状態を表す第 2 のパラメータを出力することにより、車両運動モデルとして機能する第 2 のリカレントニューラルネットワークをさらに有し、

前記最適化部は、遺伝的アルゴリズムを用いた学習則に基づき、前記第 2 のニューラルネットワークにおける前記結合重み係数の最適解をさらに決定することを特徴とする請求項 1 から 4 のいずれかに記載された車両運動モデルの生成装置。

**【請求項 6】**

前記第 1 のリカレントニューラルネットワークおよび前記第 2 のリカレントニューラルネットワークは、前記第 1 のリカレントニューラルネットワークから出力される、前記第 1 のパラメータと相関を有する状態変数が前記第 2 のニューラルネットワークに入力されるように互いに接続されており、

前記状態変数は、路面状態または車両の運動状態を表すことを特徴とする請求項 5 に記載された車両運動モデルの生成装置。

**【請求項 7】**

請求項 1 から 6 のいずれかに記載された生成装置によって生成された車両運動モデルに基づいて路面摩擦係数を推定する路面摩擦係数推定装置。

**【請求項 8】**

請求項 1 から 6 のいずれかに記載された生成装置によって生成された車両運動モデルに基づいて車両の挙動を推定する車両挙動推定装置。

**【請求項 9】**

車両の運動状態を表す車両運動モデルの生成方法において、

複数のノードを接続することによりネットワークが形成され、一のノードからの出力が所定の結合重み係数に応じて他のノードへ入力されるとともに、少なくとも一つのノードからの出力が自己のノードまたは他のノードへフィードバックされるループを有する第1のリカレントニューラルネットワークであり、コンピュータが、前記第1のニューラルネットワークにおける前記結合重み係数を遺伝子型として、遺伝的アルゴリズムを用いた学習則に基づき、前記遺伝子型の最適解を決定する第1のステップと、

前記コンピュータが、前記決定された遺伝子型の最適解に基づき、前記結合重み係数の最適解を前記第1のリカレントニューラルネットワークに対して出力する第2のステップとを有し、

前記第1のリカレントニューラルネットワークは、所定の入力情報に基づき、車両の運動状態を表すパラメータを出力することにより、車両運動モデルとして機能することを特徴とする車両運動モデルの生成方法。

#### 【請求項10】

前記第1のリカレントニューラルネットワークは、一つ以上のノードで構成される入力層と、一つ以上のノードで構成される出力層とを少なくとも含む階層型の構造を有しており、

前記第1のステップは、隣接する層間の各ノードの接続を処理対象として前記遺伝子型の最適解を決定することを特徴とする請求項9に記載された車両運動モデルの生成方法。

#### 【請求項11】

前記第1のリカレントニューラルネットワークは、一のノードの出力が自己のノードを含む前記複数のノードのすべてへ入力され、かつ、前記複数のノードのそれぞれの出力が前記一のノードへ入力されるように前記ノードのそれぞれが相互に接続されており、

前記第1のステップは、前記ノードのそれぞれにおける相互の接続を処理対象として前記結合重み係数の最適解を決定することを特徴とする請求項9に記載された車両運動モデルの生成方法。

#### 【請求項12】

前記第 1 のステップは、前記第 1 のリカレントニューラルネットワークとは異なるネットワークを構成し、かつ、前記第 1 のパラメータとは異なる車両の運動状態を表す第 2 のパラメータを出力することで車両運動モデルとして機能する第 2 のリカレントニューラルネットワークにおける結合重み係数を遺伝子型として、当該遺伝子型の最適解を決定するステップを含み、

前記第 2 のステップは、前記決定された遺伝子型の最適解に基づき、前記結合重み係数の最適解を前記第 2 のリカレントニューラルネットワークに対して出力するステップを含むことを特徴とする請求項 9 から 11 のいずれかに記載された車両運動モデルの生成方法。

### 【請求項 13】

前記第 1 のリカレントニューラルネットワークおよび前記第 2 のリカレントニューラルネットワークは、前記第 1 のリカレントニューラルネットワークから出力される、前記第 1 のパラメータと相関を有する状態変数が前記第 2 のニューラルネットワークに入力されるように互いに接続されており、

前記状態変数は、路面状態または車両の運動状態を表すことを特徴とする請求項 12 に記載された車両運動モデルの生成方法。

### 【発明の詳細な説明】

#### 【0001】

#### 【発明の属する技術分野】

本発明は、車両の運動状態を表す車両運動モデルの生成装置およびその方法に係り、特に、リカレントニューラルネットワークを用いた車両運動モデルに関する。

#### 【0002】

#### 【従来の技術】

従来より、車両の操縦安定性の向上を目的として、種々の技術の研究および開発が行われている。この類の技術の一例に、車両の運動理論に基づいて車両の挙動をモデル化した車両運動モデルがある。車両運動モデルは、ある走行状況における車両のヨー運動、横運動、或いはロール運動などを実験やシミュレーションを通してモデル化したものであり、車両に関する運動方程式に基づいて設定され

る。この車両運動モデルに基づき、車両の挙動、すなわち、運動状態を解析することにより、車両の操縦安定性を評価することができる。

#### 【0003】

また、トラクション制御、制動力制御、またはトルク配分制御といった車両の制御では、制御パラメータの演算に路面摩擦係数が用いられる。そこで、上述した車両運動モデルを用いることにより、この車両運動モデルと実際の車両の運動状態とに基づき、路面摩擦係数を推定する技術が提案されている。例えば、特許文献1には、適応制御を利用して路面摩擦係数を推定する手法が開示されている。また、特許文献2には、オブザーバにより推定した車体すべり角を、車両運動モデルに基づいた高 $\mu$ 路での基準値および車両運動モデルに基づいた低 $\mu$ 路での基準値と比較することにより、路面摩擦係数を推定する手法が開示されている。

#### 【0004】

一方、特許文献3には、ニューラルネットワークを用いて車両の運動状態を推定する手法が開示されている。具体的には、車両の運動状態を表す車両パラメータのうち測定が容易なパラメータ（例えば、前後加速度、横加速度、上下加速度、操舵トルク、前輪舵角、車速、後輪舵角等）を入力とし、測定が困難なパラメータ（横滑り角およびヨーレート）を出力とするニューラルネットワークに基づいて、横滑り角やヨーレートが推定される。また、特許文献4には、ニューラルネットワークを用い、検出された車両の走行状況に基づいて、路面摩擦係数を推定する手法が開示されている。これらの特許文献3、4において、ニューラルネットワークは、バックプロパゲーション等のアルゴリズムに従い、出力が教師信号に対応するように結合重み係数の調整（学習）が予め行われている。

#### 【0005】

##### 【特許文献1】

特開平8-2274号公報

##### 【特許文献2】

特開平10-242030号公報

##### 【特許文献3】

特開平4-138970号公報

**【特許文献4】**

特開平6-286630号公報

**【0006】****【発明が解決しようとする課題】**

ところで、上記特許文献1または2に記載された手法では、車両運動モデルを設定する場合、解算出における煩雑な演算処理を避けるため、運動方程式を線形近似している。そのため、この車両運動モデルでは、非線形領域において、車両の運動状態、すなわち、車両の挙動を正確に表現することができない可能性がある。

**【0007】**

また、特許文献3に記載された手法では、フィードフォワード型のニューラルネットワークを用いているため、ニューラルネットワークから出力された値と、ニューラルネットワークに対して入力された値とが互いに独立している。そのため、このようなニューラルネットワークでは、車両の運動状態を正確に再現できない可能性がある。なぜならば、ニューラルネットワークから出力された値（例えば、横滑り角やヨーレート）は、入力のみならず、現在の自己の値（現在値）にも依存して変化するからである。そのため、車両の運動状態を精度よく推定するためには、出力された値をフィードバックし、この値をニューラルネットワークに反映させる必要がある。この点に関し、特許文献4では、A R A Mモデルを用いて、出力値の時間遅れ値を入力層に供給することで、路面摩擦係数の推定精度の向上を図っている。しかしながら、このようなフィードバックが存在するニューラルネットワークでは、バックプロパゲーションといった学習則の原理より、その結合重み係数を学習することができないという問題があるため、路面摩擦係数の正確な推定が困難である。

**【0008】**

本発明は、かかる事情に鑑みてなされたものであり、その目的は、フィードバックループを含むリカレントニューラルネットワークを用いて車両の運動モデルを生成する新規な手法を提供することにある。

**【0009】**



## 【課題を解決するための手段】

かかる課題を解決するために、第1の発明は、車両の運動状態を表す車両運動モデルの生成装置を提供する。この生成装置は、複数のノードを接続することによりネットワークが形成され、一のノードからの出力が所定の結合重み係数に応じて他のノードへ入力されるとともに、少なくとも一つのノードからの出力が自己のノードまたは他のノードへフィードバックされるループを有する第1のリカレントニューラルネットワークと、遺伝的アルゴリズムを用いた学習則に基づいて、第1のリカレントニューラルネットワークにおける結合重み係数の最適解を決定する最適化部とを有する。ここで、第1のリカレントニューラルネットワークは、所定の入力情報に基づき、車両の運動状態を表す第1のパラメータを出力することにより、車両運動モデルとして機能する。

## 【0010】

ここで、第1の発明において、第1のリカレントニューラルネットワークは、一つ以上のノードで構成される入力層と、一つ以上のノードで構成される出力層とを少なくとも含む階層型の構造を有してもよい。この場合、最適化部は、隣接する層間の各ノードの接続を処理対象として結合重み係数の最適解を決定することが好ましい。これに対して、第1の発明において、第1のリカレントニューラルネットワークは、一のノードの出力が自己のノードを含む複数のノードのすべてへ入力され、かつ、複数のノードのそれぞれの出力が一のノードへ入力されるようにノードのそれぞれが相互に接続されていてもよい。この場合、最適化部は、前記ノードのそれぞれにおける相互の接続を処理対象として結合重み係数の最適解を決定することが好ましい。

## 【0011】

また、第1の発明において、ノードのそれぞれは、シグモイド関数、または、シグモイド関数以外の非シグモイド関数を伝達関数として用いることが好ましい。

## 【0012】

また、第1の発明において、上記生成装置は、第1のリカレントニューラルネットワークとは異なるネットワークを構成し、第1のパラメータとは異なる車両

の運動状態を表す第2のパラメータを出力することにより、車両運動モデルとして機能する第2のリカレントニューラルネットワークをさらに有していてもよい。最適化部は、遺伝的アルゴリズムを用いた学習則に基づき、第2のニューラルネットワークにおける結合重み係数の最適解をさらに決定することが好ましい。この場合、第1のリカレントニューラルネットワークおよび第2のリカレントニューラルネットワークは、第1のリカレントニューラルネットワークから出力される、第1のパラメータと相関を有する状態変数が第2のニューラルネットワークに入力されるように互いに接続されていることが好ましい。ここで、状態変数は、路面状態または車両の運動状態を表す。

#### 【0013】

また、第2の発明は、車両の運動状態を表す車両運動モデルの生成方法を提供する。この生成方法は、複数のノードを接続することによりネットワークが形成され、一のノードからの出力が所定の結合重み係数に応じて他のノードへ入力されるとともに、少なくとも一つのノードからの出力が自己のノードまたは他のノードへフィードバックするループを有する第1のリカレントニューラルネットワークであり、コンピュータが、第1のニューラルネットワークにおける結合重み係数を遺伝子型として、遺伝的アルゴリズムを用いた学習則に基づき、遺伝子型の最適解を決定する第1のステップと、コンピュータが、決定された遺伝子型の最適解に基づき、結合重み係数の最適解を第1のリカレントニューラルネットワークに対して出力する第2のステップとを有する。この場合、第1のリカレントニューラルネットワークは、所定の入力情報に基づき、車両の運動状態を表す第1のパラメータを出力することにより、車両運動モデルとして機能する。

#### 【0014】

ここで、第2の発明において、第1のリカレントニューラルネットワークは、一つ以上のノードで構成される入力層と、一つ以上のノードで構成される出力層とを少なくとも含む階層型の構造を有しており、第1のステップは、隣接する層間の各ノードの接続を処理対象として遺伝子型の最適解を決定してもよい。これに対して、第2の発明において、第1のリカレントニューラルネットワークは、一のノードの出力が自己のノードを含む複数のノードのすべてへ入力され、かつ

、複数のノードのそれぞれの出力が一のノードへ入力されるようにノードのそれぞれが相互に接続されており、第1のステップは、ノードのそれぞれにおける相互の接続を処理対象として結合重み係数の最適解を決定してもよい。

#### 【0015】

また、第2の発明において、第1のステップは、第1のリカレントニューラルネットワークとは異なるネットワークを構成し、かつ、第1のパラメータとは異なる車両の運動状態を表す第2のパラメータを出力することで車両運動モデルとして機能する第2のリカレントニューラルネットワークにおける結合重み係数を遺伝子型として、遺伝子型の最適解をさらに決定し、第2のステップは、決定された遺伝子型の最適解に基づき、結合重み係数の最適解を第2のリカレントニューラルネットワークに対して出力することが好ましい。さらに、第1のリカレントニューラルネットワークおよび第2のリカレントニューラルネットワークは、第1のリカレントニューラルネットワークから出力される、第1のパラメータと相関を有する状態変数が第2のニューラルネットワークに入力されるように互いに接続されていることが好ましい。ここで、状態変数は、路面状態または車両の運動状態を表す。

#### 【0016】

また、第3の発明は、路面摩擦係数を推定する路面摩擦係数推定装置を提供する。この摩擦係数推定装置は、上記第1の発明に記載された生成装置によって生成された車両運動モデルに基づいて路面摩擦係数を推定する。

#### 【0017】

また、第4の発明は、車両の挙動を推定する車両挙動推定装置を提供する。この車両挙動推定装置は、上記第1の発明に記載された生成装置によって生成された車両運動モデルに基づいて車両の挙動を推定する。

#### 【0018】

##### 【発明の実施の形態】

##### （第1の実施形態）

図1は、本実施形態にかかる車両運動モデルの生成装置のブロック構成図である。この生成装置は、車両の運動状態を表す車両運動モデルを生成する。この生

成装置 1 としては、CPU、RAM、ROM、入出力インターフェース等で構成されたコンピュータを用いることができる。図 1 には明記しないが、生成装置 1 には、キーボードおよびマウスを含む入力装置、CRT や液晶ディスプレイ等の表示装置などが接続されている。オペレータは、表示装置に表示された情報に基づいて、入力装置を操作して、必要な情報の入力等を行うことができる。生成装置 1 は、これを機能的に捉えた場合、最適化部 10 と、車両運動モデル部 20 とで構成されている。

#### 【0019】

最適化部 10 は、遺伝的アルゴリズムを用いた学習則に基づいて演算を行い、演算結果として所定のパラメータを車両運動モデル部 20 に対して出力する。後述するように、車両運動モデル部 20 を構成する各推定モジュール 21～24 がリカレントニューラルネットワークで構成されている関係上、このパラメータは、リカレントニューラルネットワークの結合重み係数  $K_{ij}$ 、およびしきい値  $\theta_j$  がこれに該当する。ここで、「リカレントニューラルネットワーク」とは、フィードバックループを有するニューラルネットワークをいう。

#### 【0020】

車両運動モデル部 20 は一つ以上の推定モジュール（本実施形態では、推定モジュール 21～24）で構成されており、これらの推定モジュール 21～24 は各々が異なる一つの運動状態を表す車両運動モデルとして機能する。各推定モジュール 21～24 は、リカレントニューラルネットワーク（以下、単に「RNN」という）で構成されており、所定の入力情報に基づき、車両の運動状態を表すパラメータ（以下、「車両パラメータ」という）を出力する。本実施形態では、車両運動モデル部 20 から 4 つの車両パラメータが出力される。具体的には、推定モジュール 21 は車両パラメータとしてヨーレートの推定値を出力し、推定モジュール 22 は車両パラメータとして横加速度（以下、単に「横 G」という）の推定値を出力する。また、推定モジュール 23 は車両パラメータとしてロールの推定値を出力し、推定モジュール 24 は車両パラメータとしてピッチの推定値を出力する。

#### 【0021】

図2は、推定モジュールとして機能するRNNの構造を示す説明図である。以下、RNNを説明するにあたり、ヨーレート用の推定モジュール21を構成するRNNを用いる。ただし、他の推定モジュール22～24を構成するRNNについても基本的な構造に変わりはないので、他の推定モジュール22～24については説明を省略する。このRNNでは、複数のノード $N_n$ （図2では例示的にノード $N_1 \sim N_{18}$ ）を接続することによりネットワークが形成されており、これらのノード $N_n$ が階層的に区分けされ、入力層、中間層および出力層で構成された階層型の構造になっている。各層を構成するノード $N_n$ の数は、オペレータによって適宜設定される。この場合、オペレータは、ノード $N_n$ の数を増やすことで得られる解の信頼性の向上と、ノード $N_n$ の数を減らすことで得られる処理速度の向上という相反する両者の関係を考慮した上で、各層が最適なノード数となるようにネットワーク構造を決定する。

#### 【0022】

出力層には、基本的に、車両パラメータを出力するためのノード $N_n$ （ノード $N_{16}$ ）が一つ設定されている。ただし、本実施形態では、後述するように出力層から入力層に対するフィードバックループが存在しており、入力層に対するフィードバックを多重的に行うべく、フィードバックのみを目的としたノード $N_{17}$ がさらに設定されている。また、図2において、ヨーレート用の推定モジュール21を構成するRNNは、車両パラメータとは別個に、状態変数 $P$ を出力するためのノード $N_{18}$ が設定されている。なお、このノード $N_{18}$ から出力される状態変数 $P$ は、横 $G$ 、ロールおよびピッチ用の推定モジュール22～24を構成するRNNの入力層ノード $N_n$ に入力される。

#### 【0023】

入力層には、入力情報を入力するために必要な個数分のノード $N_n$ が設定されている。ここで、入力情報とは、RNNが車両パラメータを出力するために必要とされる情報をいい、本実施形態では、ハンドル角、ハンドル角速度、ハンドル角加速度、ステアリング反力、車体速度、車体加速度などがこれに該当する。また、出力層ノード $N_{16}$ 、 $N_{17}$ の出力を入力層にフィードバックさせる関係上、これに対応するノード $N_7 \sim N_{10}$ も入力層に設定されている。なお、図2では、ヨ

ーレート用の推定モジュール 21 を構成する RNN が図示されているため特に明記していないが、他の推定モジュール 22 ~ 24 には、図 1 に示した状態変数  $P$  を入力するためのノード  $N_n$  がさらに設定されている。

#### 【0024】

一方、中間層のノード  $N_n$  としては、上述したような関係を考慮した上で、オペレータの経験などを頼りに必要な個数分のノード  $N_n$  が用意されている。図 2 に示す例では、中間層は、ノード  $N_{11} \sim N_{15}$  の 5 つのノード  $N_n$  で構成されている。

#### 【0025】

このようにして各層を構成するノード  $N_n$  が設定されると、ノード間の接続は自動的に決定される。階層型の RNN では、ある層を構成する各ノード  $N_n$  の出力は後段の層を構成するすべてのノード  $N_n$  へ入力されるようにノード間の接続が決定される。例えば、図 2 に示すように、入力層のノード  $N_1$  は、その出力が中間層のすべてのノード  $N_{11} \sim N_{15}$  へ入力されるように接続されるといった如くである。

#### 【0026】

また、本実施形態の特徴の一つとして、この RNN は、あるノード  $N_n$  の出力をフィードバックさせるループを有している。具体的には、図 2 に示すように出力層ノード  $N_{16}$  の出力は、車両パラメータの一つであるヨーレートとして出力されるととともに、第 1 の遅延回路  $Z^{-1}$  によって一サイクルだけ遅延された後に、入力層ノード  $N_7$  に入力される。また、その第 1 の遅延回路  $Z^{-1}$  からの出力は、その後段に設けられた第 2 の遅延回路  $Z^{-1}$  によって更に一サイクルだけ遅延された後に（したがって、ノード  $N_{16}$  の出力に対応する初期の入力からは二サイクルだけ遅延された後に）、入力層ノード  $N_8$  に入力される。一方、出力層ノード  $N_{17}$  の出力は、上記第 1 および第 2 の遅延回路  $Z^{-1}$  とは異なる第 3 の遅延回路  $Z^{-1}$  によって一サイクルだけ遅延された後に、入力層ノード  $N_9$  に入力される。また、第 3 の回路  $Z^{-1}$  からの出力は、その後段に設けられた第 4 の遅延回路  $Z^{-1}$  によって更に一サイクルだけ遅延された後（したがって、ノード  $N_{17}$  の出力に対応する初期の入力からは二サイクルだけ遅延された後）に、入力層ノード  $N_{10}$  に入力

される。

### 【0027】

このようなRNNにおいて、それぞれのノード $N_n$ は、所定の伝達関数に従い、所定個数の入力 $y_i$ に対して一つの出力 $Y_i$ を生成する。そして、生成された出力 $Y_i$ は、後段の層を構成するノード $N_n$ に対して出力される。具体的には、それぞれのノード $N_n$ は、入力データ $y_i$ に対して数式1, 2に示す計算を行い、その演算結果を出力データ $Y_j$ として出力する。ここで、 $K_{ij}$ は $n=i$  ( $i=1\sim 15$ ) 番目のノード $N_i$ と、 $n=j$  ( $j=11\sim 15$  ( $i=1\sim 10$ ),  $j=16\sim 18$  ( $i=11\sim 15$ )) 番目のノード $N_j$ との間の結合重み係数であり、 $\theta_j$ はしきい値である。

### 【数1】

$$X_j = \sum K_{ij} \cdot y_i \quad (i=1\sim n)$$

### 【数2】

$$Y_j = 1 / (1 + \exp(- (X_j - \theta_j)))$$

### 【0028】

これらの数式1, 2から分かるように、あるノード $N_n$ からの出力は、所定の結合重み係数 $K_{ij}$ に応じて他のノード $N_n$ へ入力される。ここで、数式2は、シグモイド関数と呼ばれ、RNNにおけるノードの関数として一般に用いられる。シグモイド関数は、0から1まで連続的に変化し、しきい値 $\theta_j$ が小さくなるにつれて、ステップ関数に近づいていく。

### 【0029】

RNNを用いて車両パラメータを推定する場合、その推定結果の精度向上を図るためには、結合重み係数 $K_{ij}$ としきい値 $\theta_j$ とを適切に調整(学習)する必要がある。これらの結合重み係数 $K_{ij}$ としきい値 $\theta_j$ との最適解は、上述した最適化部10によって学習され適宜決定される。最適化部10によって処理対象となる接続は、フィードバックのループを除く隣接する層間の各ノードの接続となる。

### 【0030】

図3は、遺伝的アルゴリズムを用いた重み係数 $w_{ij}$ としきい値 $\theta_j$ との最適解の決定手順を示すフローチャートであり、このフローチャートに示す処理は最適

化部 10 によって行われる。この最適化部 10 は、それぞれの推定モジュール 21 ~ 24 に対して以下に示す処理を行う。ここでは、ヨーレート用の推定モジュール (RNN) 21 を例に説明するが、他の推定モジュール (RNN) 22 ~ 24 について行われる処理も変わりはないので、他の推定モジュール 22 ~ 24 については説明を省略する。

#### 【0031】

まず、ステップ 1 において、遺伝子型で構成される個体が N 個だけ集合した初期個体集団が生成される。本実施形態において、遺伝子型は、結合重み係数  $K_{ij}$  およびしきい値  $\theta_j$  が該当する。この場合、一つの個体は、RNN におけるすべての結合重み係数  $K_{ij}$ 、およびしきい値  $\theta_j$  を含んだ遺伝子型で構成される。また、初期個体集団は、このような個体が N 個だけ集合したものであり、個体毎にいろいろな値を有する遺伝子型  $K_{ij}$ 、 $\theta_j$  で構成される。各個体 1 ~ N を構成する遺伝子型  $K_{ij}$ 、 $\theta_j$  は、例えば、乱数によって初期値が決定される。すなわち、個体 1 ~ N 毎に結合重み係数  $K_{ij}$  としきい値  $\theta_j$  とを RNN に代入すれば、結合重み係数  $K_{ij}$  としきい値  $\theta_j$  が確定された N 個の RNN が得られる。

#### 【0032】

ステップ 2 において、適応度 A が算出される。適応度 A を算出する前提として、オペレータは、実験やシミュレーションを通じ、所定の条件下において実際に車両が示す車両パラメータ（以下、「実車両パラメータ」という）を予め取得しておく。そして、オペレータは、この所定の条件と、実車両パラメータとの対応関係を記述したマップを生成装置 1 の ROM に格納しておく。このマップに記述された所定の条件は、フィードバック要素を除く入力層ノード  $N_n$  に入力されるパラメータであり、ハンドル角、ハンドル角速度、ハンドル角加速度、ステアリング反力、車体速度および車体加速度がこれに該当する。このような前提に基づき、最適化部 10 は、マップを参照し、これらの条件を RNN の入力層ノード  $N_1 \sim N_6$  にそれぞれ入力し、出力層ノード  $N_{16}$  からの出力として、車両パラメータの推定値（以下、「推定車両パラメータ」という）を取得する。そして、この推定車両パラメータと、実車両パラメータとに基づき、数式 3 に示す評価関数を用いて適応度 A を算出する。



## 【数式 3】

$$A = \sum |V_t - V_c|$$

## 【0033】

図4は、評価関数を説明する概略図である。同図には、実車両パラメータ（例えば、ヨーレート）の時系列的な変化が実線で示されており、推定車両パラメータ（例えば、ヨーレート）の時系列的な変化が点線で示されている。数式3に示すように、評価関数は、所定時間における、実車両パラメータ  $V_t$  と推定車両パラメータ  $V_c$  との差分（絶対値）の総和である（図4に示すハッチング領域の面積）。すなわち、この評価関数は、推定ヨーレートが実ヨーレートに近ければ近いほど、適応度  $A$  が低くなるように設定されている。

## 【0034】

最適化部10は、各個体1～Nについて適応度  $A$  を算出し、適応度  $A$  が低い順に、個体1～Nを並び替える。すなわち、個体集団中の各個体1～Nは、推定車両パラメータが実車両パラメータに近いものから順番に、個体1～Nとして新たに並び替えられる。

## 【0035】

ステップ3において、個体1に関する適応度  $A$  の値が、判定適応度  $A_{error}$  の値より大きいかが判断される。この判定適応度  $A_{error}$  は、推定ヨーレートと実ヨーレートとが実質的に同一とみなせるような適応度  $A$  の最大値として設定されている。したがって、このステップ3において、肯定判定された場合（適応度  $A$  が判定適応度  $A_{error}$  よりも大きい場合）、続くステップ4に進む。一方、このステップ3において、否定判定された場合（適応度  $A$  が判定適応度  $A_{error}$  以下の場合）、後段のステップ6に進む。

## 【0036】

ステップ4において、周知の手法を用いて、個体1～Nが選択・淘汰される。このような選択・淘汰の手法としては、逆ルーレット式選択、ランク方式選択、トーナメント式選択等が挙げられる。このステップ4の処理により、ある個体（或いは、個体群）が選択され、選択された個体が個体集団の中から削除される。この削除された個体の位置には、例えば、適応度  $A$  が低い方から同数の個体に移

すことで、母集団を構成する個体の数が維持される。

#### 【0037】

ステップ5において、次世代の個体母集団が生成される。具体的には、最適化部10は、集団中の個体を構成する遺伝子型 $K_{ij}$ ,  $\theta_j$ を突然変異および交叉させる。突然変異は、ある個体中の任意の遺伝子型 $K_{ij}$  (または $\theta_j$ ) を例えば乱数により選び、乱数により発生した値に変化させる。また、交叉は、乱数により選択したある個体群において、これもまた乱数により選択された遺伝子型 $K_{ij}$  (または $\theta_j$ ) の値を互いに交換する。ただし、突然変異および交叉を行う個体の選択手法としては、乱数によって選び出すことに限定されず、適応度 $A$ が最も低い個体については、その個体を維持するために、突然変異および交叉を行わないようにしてもよい。そして、ステップ2以降の処理に戻り、個体1の適応度 $A$ が判定適応度 $A_{error}$ 以下となるまで、上述した処理が繰り返される。

#### 【0038】

一方、ステップ3の肯定判定にともなうステップ6では、個体1を構成する遺伝子型 $K_{ij}$ ,  $\theta_j$ が最適解として決定され、本ルーチンを抜ける。この場合、最適化部10は、この個体1を構成する遺伝子型 $K_{ij}$ ,  $\theta_j$ に基づき、これらの遺伝子型 $K_{ij}$ ,  $\theta_j$ の値を、それぞれ対応する結合重み係数 $K_{ij}$ およびしきい値 $\theta_j$ の最適解として決定する。そして、決定された最適解がRNNに対して出力され、各推定モジュール21~24において、この最適解がRNNの結合重み係数 $K_{ij}$ と、しきい値 $\theta_j$ とに設定される。これにより、推定モジュール21~24を含む車両運動モデル部20が単独で、或いは、この生成装置1自体が、車両運動モデルとして機能する。

#### 【0039】

図5~図7はRNNの学習結果を示す図であり、図5は1世代目の個体に関する学習結果、図6は100世代目の個体に関する学習結果、図7は30000世代目の個体に関する学習結果を示す。これらの図には、上述した所定の条件 (例えば、図8に示すようなハンドル角) を与えた場合の実車両パラメータ (ヨーレート) が細い実線で描かれており、同一の条件を与えた場合の推定車両パラメータ (ヨーレート) がそれよりも太い実線で描かれている。これらの図から分かる

ように、1世代目では、両者の線は振幅の周期が同様の傾向を示すものの、値として差が大きく、推定車両パラメータは実車両パラメータを再現し切れていない。100世代目では、両者の線は基本的に同様の傾向を示すものの、極大（或いは極小）点付近で相違が見られる。そして、30000世代目では、全域に亘り両者の線はほぼ同じ値を示し、実車両パラメータを示す細い実線が、推定車両パラメータを示す太い実線によって覆われている。このように、例えば、30000世代といった程度まで学習を行うことで、推定パラメータは実車両パラメータを高レベルで再現することができる。すなわち、遺伝的アルゴリズムを用いて学習することで、フィードバックのループを含むRNNの重み係数 $K_{ij}$ の最適解を有効に見つけ出すことができることが理解できる。

#### 【0040】

このように、本実施形態によれば、遺伝的アルゴリズムを用いて、RNNの結合重み係数 $K_{ij}$ （さらには、しきい値 $\theta_j$ ）の学習を行い、その最適解を決定している。フィードバックを含むRNNは、バックプロパゲーションといった最急降下法の原理に基づいた学習則を行うことができないという問題があるが、本実施形態では、遺伝的アルゴリズムを用いることでこれを解決することができる。

#### 【0041】

また、RNNを用いることで、車両パラメータを含む出力層ノード $N_n$ の出力が、入力層ノード $N_n$ にフィードバックされている。このため、RNN中にフィードバックされた値が反映されるので、本実施形態のRNNは、自己の以前の出力を加味した状態で車両パラメータを推定することができる。したがって、本実施形態に示す手法は、フィードフォワード型のニューラルネットワークよりも実際の車両の運動状態に即した、すなわち、車両の運動状態の再現性に優れた車両運動モデルを生成することができる。

#### 【0042】

また、本実施形態では、各推定モジュール21～24が一つの車両パラメータを出力している。例えば、一つのRNNにおいて、出力層に上述した4つの車両パラメータを出力させるノード $N_n$ を設け、これにより、4つのRNNを一つのRNNで代替することもできる。しかしながら、本実施形態のシステム構成によ

れば、車両パラメータを出力するノード $N_n$ を単一とすることで、各RNNを構成するノード $N_n$ の数を減らすことができる。これにより、最適化部10によって行われる各推定モジュール21～24に対する学習速度を向上させることができる。また、学習速度が向上すれば、遺伝的アルゴリズムを用いて学習を行う際に、初期個体集団中の個体数を増やし、様々な個体を個体集団に含め学習を行うことができる。これにより、遺伝子型 $K_{ij}$ 、 $\theta_j$ の最適解をより精度よく決定することができる。また、ノード数が少ないと、その組み合わせが小規模となるので、遺伝的アルゴリズムにおける解空間の次元数が下がり、最適解が発見し易くなるという効果を奏する。

#### 【0043】

なお、推定モジュール21～24から出力される車両パラメータは、共通の車両に関する運動状態を表すものであり、たとえその種類が異なったとしても、車両の運動に起因して互いに同期して変化する必要がある。そのため、本実施形態では、例示的に、ヨーレート用の推定モジュール21から状態変数 $P$ を出力させ、この状態変数 $P$ を推定モジュール22～24に入力させている。ヨーレート用の推定モジュール21から出力される状態変数 $P$ は、遺伝的アルゴリズムを用いて結合重み係数 $K_{ij}$ の学習を行うことにより、推定モジュール21の出力結果である車両パラメータ（具体的には、ヨーレート）と高い相関を有する。例えば、この状態変数 $P$ は、車両のヨーレートに応じた車両の運動状態または路面状態を表している。このため、状態変数 $P$ が入力される推定モジュール22～24では、ヨーレートと相関を有する状態変数 $P$ を加味した状態で結合重み係数 $K_{ij}$ の学習が行われることになるので、4つの推定モジュール21～24を構成するRNNの同期をとることができる。すなわち、状態変数 $P$ は、推定モジュール22～24において推定モジュール21に対する同期付けの基準となる値として作用する。よって、本実施形態のシステム構成では、それぞれの推定モジュール21～24が独立して構成される場合と比較して、各車両パラメータがより実車の運動状態に近い値を再現することができる。

#### 【0044】

なお、このような作用を奏する状態変数 $P$ としては、本実施形態に示すようなヨ

ーレート用の推定モジュール 21 からの出力のみに限定されず、他の推定モジュール 22～24 からの出力のいずれかを用いてもよい。ただし、車両のパラメータのうち、ヨーレートは他の車両パラメータと比べ、比較的精度良くその値を検出することができるので、このヨーレート用の推定モジュール 21 から状態変数  $P$  を出力することが好ましい（すなわち、状態変数  $P$  の信頼性の向上）。また、これらの推定モジュール 21～24 から各々状態変数  $P$  を出力させ、各状態変数  $P$  を出力側の推定モジュールとは異なる推定モジュールに入力させ、相互に関連（同期）を持たせるような構成にしてもよい。なお、上述した実施形態では、状態変数  $P$  をヨーレートと相関を有する、路面状態または車両の運動状態を表す変数として取り扱った。ただし、状態変数  $P$  がヨーレートと相関を有するという観点からすれば、ノード N16 から出力される車両パラメータ（ヨーレート）そのものを状態変数  $P$  として用いてもよい。

#### 【0045】

なお、本実施形態において、車両運動モデル部 20 は、4 つの推定モジュール 21～24 で構成されるが、本発明はこれに限定されるものではない。推定モジュールの数は、必要とする車両パラメータに応じて任意に決定することができる。また、車両パラメータも、ヨーレート、横  $G$ 、ロールおよびピッチの 4 つにのみ限定されず、例えば、車体すべり角、前輪すべり角、後輪すべり角、車輪と路面との間の摩擦係数といったその他のパラメータをさらに含めてもよい。

#### 【0046】

また、本実施形態では、マップを参照し、これを RNN の出力と比較することで、RNN の結合重み係数  $K_{ij}$ 、しきい値  $\theta_j$  の学習を行っているが、生成装置 1 を実車に搭載し、リアルタイムで学習を行ってもよい。この場合、入力に相当するハンドル角、ハンドル角速度、ハンドル角加速度、ステアリング反力、車体速度、車体加速度をセンサ等から検出、或いは検出値に基づき算出し、RNN の入力させる。そして、出力に相当する車両パラメータをセンサで検出し、この検出値と RNN の出力とを比較するといった如くである。

#### 【0047】

（第 2 の実施形態）

図9は、第2の実施形態にかかる各推定モジュール21～24を構成するRNNのネットワーク構造を示す説明図である。なお、同図に示す例では、便宜上、ノードNnの一部が省略して描かれている。各推定モジュール21～24は複数のノードNnで構成されるRNNであり、結合重み係数 $K_{ij}$ としきい値 $\theta_j$ との最適解を遺伝的アルゴリズムを用いて決定する点については、第1の実施形態と同様である。しかしながら、本実施形態は、前提となるRNNのネットワーク構造が第1の実施形態のそれと相違する。第1の実施形態におけるRNNは階層型の構造を有し、各層を構成するノードNnの数を設定することにより、ノードNn間の接続は予め決定される。一方、第2の実施形態におけるRNNは、あるノードNnが自己を含むすべてのノードNnと結合するように、複数のノードが相互に接続されている。したがって、例えば、ノードN1の出力は、このノードN1を含むすべてのノードN1～Nnへ入力され、かつ、すべてのノードN1～Nnの出力がノードN1へ入力される。

#### 【0048】

図10は、ノード間の結合重み係数 $K_{ij}$ の対応関係を示した説明図である。このようなネットワークにおいて、ノード間の結合重み係数 $K_{ij}$ は図10に示すマトリクスとして表現される。このマトリクスは、フィードフォワード、フィードバックといった種類を問わず、すべてのノード間の接続に関する結合重み係数 $K_{ij}$ を表している。本実施形態では、このようなネットワーク構造において、上述した最適化部10が、複数のノードの相互の接続を処理対象として結合重み係数 $K_{ij}$ およびしきい値 $\theta_j$ の最適解を決定する。

#### 【0049】

結合重み係数 $K_{ij}$ 、しきい値 $\theta_j$ の最適解を決定する手法は、第1の実施形態のそれと基本的に同じであるため、ここでは概略のみを説明し、その詳細な説明は省略する。具体的には、まず、図10に示す結合重み係数 $K_{ij}$ （すなわち、 $K_{11} \sim K_{nn}$ ）およびしきい値 $\theta_j$ を遺伝子型とし、いろいろな値をもつ遺伝子型で構成される個体を複数用意する（初期個体集団の生成）。そして、これらの個体ごとに適応度Aを算出する。この場合、ネットワークを構成するノードNnの中から任意に6つのノードNnを選択し、上記マップに基づき、ハンドル角、ハン

ドル角速度、ハンドル角加速度、ステアリング反力、車体速度および車体加速度を選択されたノード  $N_n$  に入力する。そして、入力に用いたノード  $N_n$  とは異なるノード  $N_n$  を任意に一つ選択し、そのノード  $N_n$  から出力を得る。そして、この出力と、マップに記述された車両パラメータとに基づいて、数式 3 に示す評価関数を用いて適応度  $A$  を算出する。そして、図 3 に示す処理と同様、適応度  $A$  が判定適応度  $A_{error}$  以下となるまで、選択・淘汰、次世代の個体集団の生成が繰り返され、最適な遺伝子型  $K_{ij}$ 、 $\theta_j$  が決定される。これにより、RNN における結合重み係数  $K_{ij}$  およびしきい値  $\theta_j$  の最適解が決定される。

#### 【0050】

このように本実施形態によれば、ネットワークの結合状態を初期的に限定せずに、フィードフォワード、フィードバックを含み、すべてのノード間が接続されたネットワーク構造を有する RNN を採用している。このようなネットワーク構成であっても、遺伝的アルゴリズムを用いることで、結合重み係数  $K_{ij}$ （およびしきい値  $\theta_j$ ）を決定することができる。この場合、決定された結合重み係数  $K_{ij}$  が値として「0」となれば、ノード  $N_i$  と、ノード  $N_j$  との結合が不要であることを意味している。すなわち、形式的にはすべてのノード  $N_n$  がネットワークとして結合しているが、この結合重み係数  $K_{ij}$  の値に応じて必要なノードのみが実質的に残されることになる。換言すれば、遺伝的アルゴリズムにより結合重み係数  $K_{ij}$  を学習させることにより、等価的に、車両パラメータを算出するために必要なノードが選択されることになる。当然、学習の結果、その結合重み係数  $K_{ij}$  の値によっては、実質的に図 2 に示すようなネットワーク構成が出来上がることも予想される。しかしながら、このような場合、すべてのノード  $N_n$  の接続がなされた RNN のなかから、必要なノードのみが選択され、そのネットワーク構成が車両パラメータを推定する上で最適な構造であることが遺伝的アルゴリズムによって保証されるという効果を奏する。

#### 【0051】

なお、上述した第 1 および第 2 の実施形態では、伝達関数をシグモイド関数を前提として説明を行ったが、遺伝的アルゴリズムを用いて学習を行うのであれば、RNN を構成するノードの伝達関数は、シグモイド関数に限定されない。例え

ば、図 11 に示すような、非シグモイド関数を伝達関数として用いてもよい。同図 (a) は、入力に対して出力がヒステリシスと呼ばれる非線形特性を示す関数の一例を示す。また、同図 (b) ~ (d) には、二値化、不感帯、リミッタと呼ばれる非線形特性を示す関数の一例が示されている。

#### 【0052】

また、伝達関数としては、このような非線形特性を示す関数だけでなく、順序回路的な要素を含む関数を用いてもよい。すなわち、過去の入力系列によって出力が決まるような関数を用いることができる。このような関数としては、時間遅れ ( $Z^{-1}$ )、ピークホールド (所定のインターバル間のピーク値を出力する)、最大値 (時系列的なピーク値を出力する)、積分、微分といったものが挙げられる。

#### 【0053】

このように、非シグモイド関数をノード Nn の伝達関数に含めることで、シグモイド関数では表現しきれないような入出力特性をも表現できる車両運動モデルを生成することができる。よって、このような車両運動モデルは、例えば、車両の後輪がスリップし、車両運動モデルが一気に激変してしてしまうような場合の入出力応答を表現することができる。これにより、車両の運動状態の再現性を向上させることができる。

#### 【0054】

なお、上述した車両運動モデルの生成装置、或いは、この装置によって生成された車両運動モデルは、路面摩擦係数を推定する装置や車両の挙動を推定する装置の一部に組み込まれて使用することができる。例えば、路面摩擦係数推定装置にこの車両運動モデルを適用する場合には、路面摩擦係数の高い路面での車両の運動状態を学習させた高  $\mu$  用車両運動モデルと、路面摩擦係数の低い路面で車両の運動状態を学習させた低  $\mu$  用車両運動モデルとを用意しておく。そして、各車両運動モデルに、現在の車両に関するハンドル角、ハンドル角速度、ハンドル角加速度、ステアリング反力、車体速度、車体加速を入力し、ヨーレートといった車両パラメータを取得する。また、取得した車両パラメータに相当する車両の運動状態をセンサ等で検出し、検出された値を、車両運動モデルから取得した値と



比較する。これにより、その値が近似する傾向を示す、一方の車両運動モデルの学習状況に相当する路面状態を、現在の路面摩擦係数として推定することができる。一方、車両挙動推定装置は、車両運動モデルに、現在の車両に関するハンドル角、ハンドル角速度、ハンドル角加速度、ステアリング反力、車体速度、車体加速を入力し、ヨーレートといった車両パラメータを取得する。そして、取得した車両パラメータに基づき、車両がどのような挙動を示すか推定するといった如くである。また、この車両運動モデルを用いることにより、車両の挙動、車両の乗り心地を評価することもできる。

### 【0055】

#### 【発明の効果】

このように本発明によれば、遺伝的アルゴリズムを用いることにより、フィードバックのループを有するリカレントニューラルネットワークの結合重み係数の最適解を決定することができる。また、車両運動モデルにリカレントニューラルネットワークを用いることにより、リカレントニューラルネットワーク中にフィードバック要素が考慮されることになる。したがって、フィードフォワード型のリカレントニューラルネットワークよりも実際の車両の運動状態に即した、すなわち、車両の運動状態の再現性が向上した車両運動モデルを生成することができる。

#### 【図面の簡単な説明】

【図1】 本実施形態にかかる車両運動モデルの生成装置のブロック構成図

【図2】 推定モジュールとして機能するRNNの構造を示す図

【図3】 遺伝的アルゴリズムを用いた重み係数としきい値との最適解の決定手順を示すフローチャート

【図4】 評価関数の概念を示す説明図

【図5】 RNNの1世代目の個体に関する学習結果を示す図

【図6】 RNNの100世代目の個体に関する学習結果を示す図

【図7】 RNNの30000世代目の個体に関する学習結果を示す図

【図8】 RNNに与えた条件の一例を示す図

【図9】 第2の実施形態にかかる各推定モジュールを構成するRNNのネッ

## トワーク構造を示す説明図

【図 1 0】 ノード間の結合重み係数の対応関係を示した説明図


【図 1 1】 伝達関数の一例を示す説明図

## 【符号の説明】

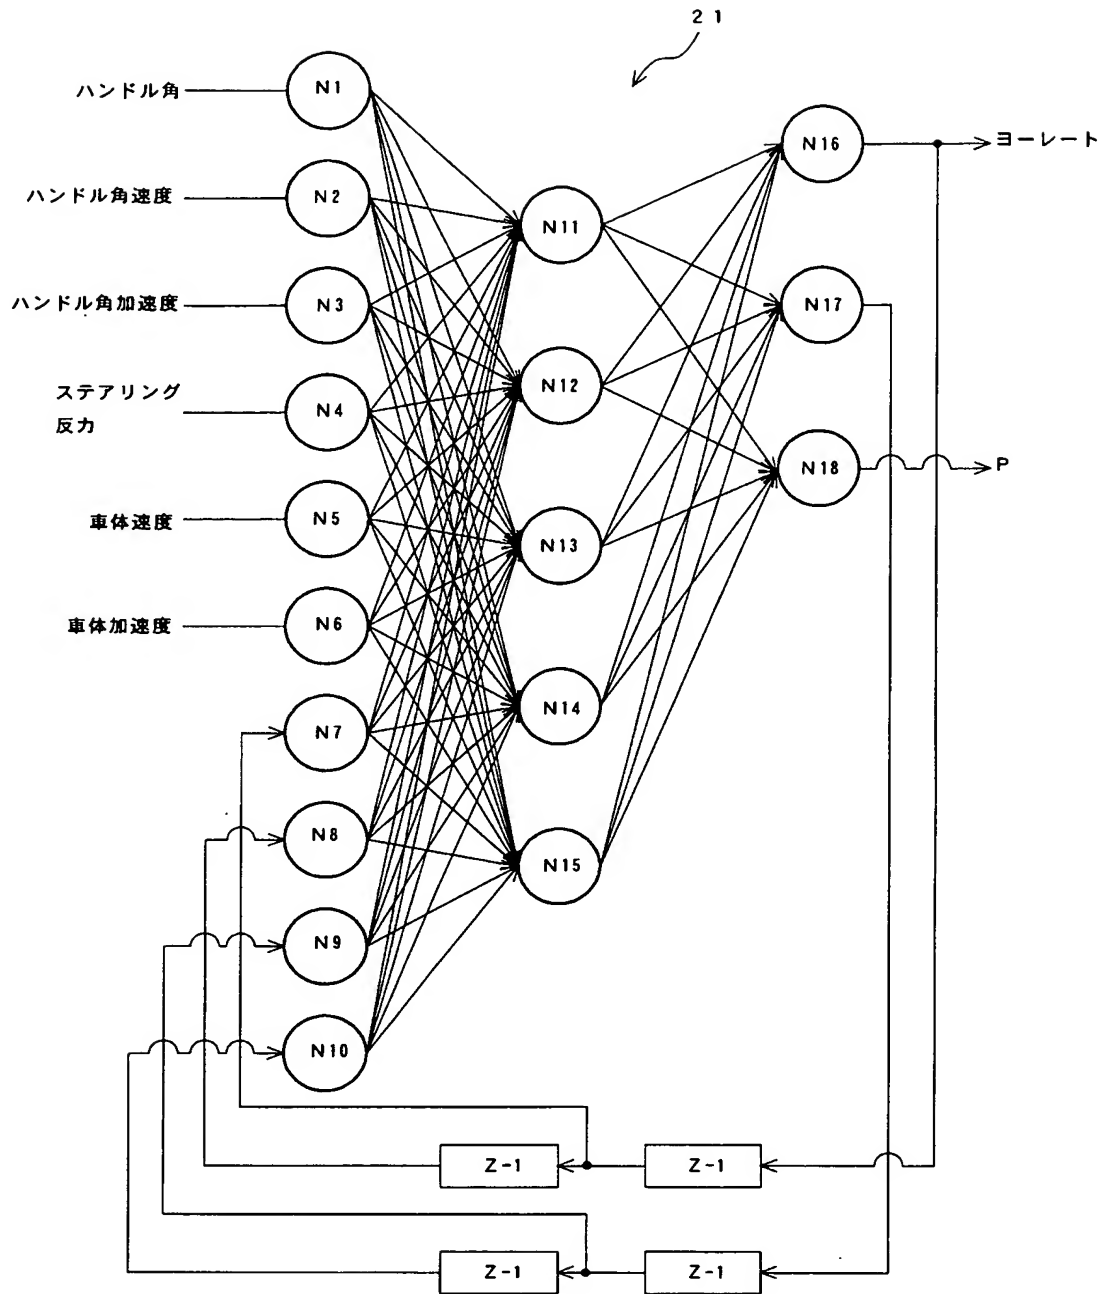
- 1 生成装置
- 1 0 最適化部
- 2 0 車両運動モデル部
- 2 1 推定モジュール
- 2 2 推定モジュール
- 2 3 推定モジュール
- 2 4 推定モジュール

【書類名】 図面

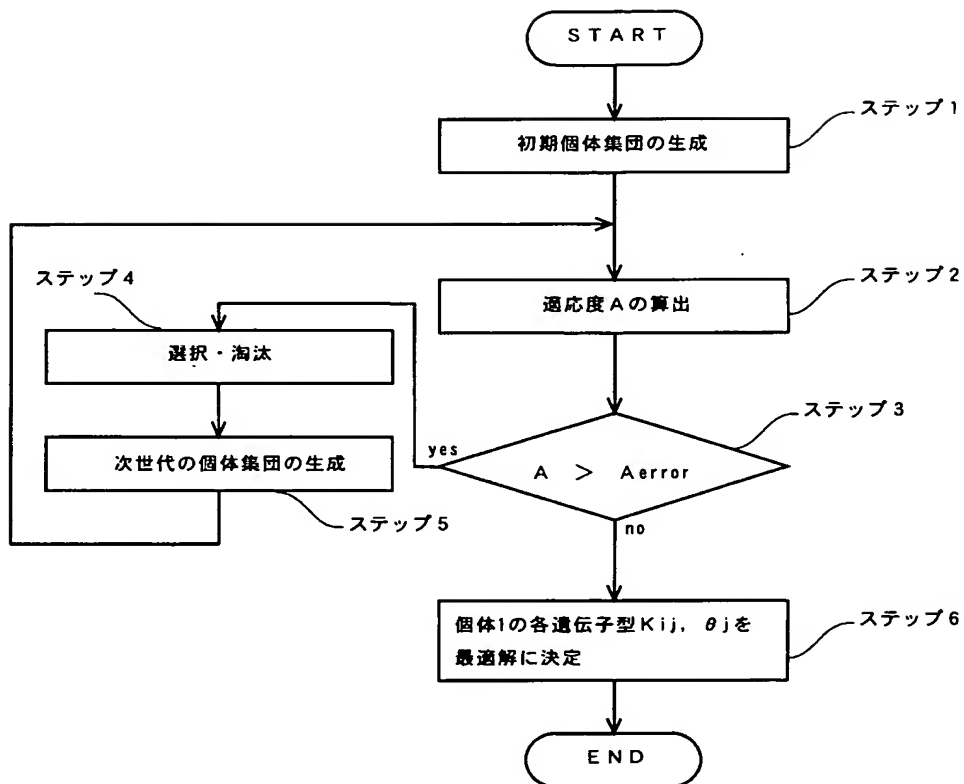
【図 1】




【図 2】




【図3】




【図 4】




【図 5】




【図 6】




【図 7】



【図 8】



【図 9】









【図 10】

出力 入力	ノード N1	ノード N2	...	ノード Nn-1	ノード Nn
ノード N1	K11	K12		K1(n-1)	K1n
ノード N2	K21	K22		K2(n-1)	K2n
.					
.					
.					
ノード Nn-1	K(n-1)1	K(n-1)2		K(n-1)(n-1)	K(n-1)n
ノード Nn	Kn1	Kn2		Kn(n-1)	Kn n

【図 11】



【書類名】 要約書

【要約】

【課題】 RNNを用いて車両の運動モデルを生成する新規な手法を提供する。

【解決手段】 複数のノードが接続されることによりネットワークが形成され、一のノードからの出力が所定の結合重み係数に基づいて他のノードへ入力されるとともに、少なくとも一つのノードからの出力が自己のノードまたは他のノードへフィードバックされるループを有する第1のリカレントニューラルネットワーク21と、遺伝的アルゴリズムを用いた学習則に基づいて、第1のリカレントニューラルネットワークにおける結合重み係数の最適解を決定する最適化部10とを有する。この場合、第1のリカレントニューラルネットワークは、所定の入力情報に基づき、車両の運動状態を表す第1のパラメータを出力することで、車両運動モデルとして機能する。

【選択図】 図1

特願 2003-041507

出 願 人 履 歴 情 報

識別番号

[000005348]

1. 変更年月日

1990年 8月 9日

[変更理由]

新規登録

住 所

東京都新宿区西新宿一丁目7番2号

氏 名

富士重工業株式会社